

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CAMPUS DE ILHA SOLTEIRA**

JOÃO PAULO MARTINS VELOSO

**DETERMINAÇÃO DAS MELHORES CURVAS DE CONTROLE VOLT-VAR PARA
INVERSORES INTELIGENTES USANDO ALGORITMO EVOLUCIONÁRIO**

Ilha Solteira, SP
2025

JOÃO PAULO MARTINS VELOSO

**DETERMINAÇÃO DAS MELHORES CURVAS DE CONTROLE VOLT-VAR PARA
INVERSORES INTELIGENTES USANDO ALGORITMO EVOLUCIONÁRIO**

Trabalho de Conclusão de Curso
apresentada à Faculdade de Engenharia de
Ilha Solteira – UNESP como parte dos
requisitos para obtenção do título de bacharel
em Engenharia Elétrica.

Prof. Dr. Jonatas Boas Leite
Orientador

FICHA CATALOGRÁFICA

Desenvolvida pela Diretoria Técnica de Biblioteca e Documentação

Veloso, João Paulo Martins.

V443d Determinação das melhores curvas de controle Volt-Var para inversores inteligentes usando algoritmo evolucionário / João Paulo Martins Veloso. -- Ilha Solteira: [s.n.], 2025
48 f. : il.


Trabalho de conclusão de curso (Graduação em Engenharia Elétrica) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira, 2025

Orientador: Jonatas Boas Leite
Inclui bibliografia


1. Algoritmo genético. 2. Inversores inteligentes. 3. Controle Volt-Var. 4. Controle Volt-Watt. 5. Sistemas de distribuição.

ATA DE DEFESA DE TRABALHO DE GRADUAÇÃO


Aos oito dias do mês de dezembro do ano de dois mil e vinte e cinco, o discente **João Paulo Martins Veloso**, matriculado sob o nº 172053919, tendo como banca examinadora o seu orientador, o Prof. Dr. Jonatas Boas Leite, o Dr. Lucas do Carmo Yamaguti e o Mestrando Mikael de Freitas Amaral, apresentou o Trabalho de Graduação intitulado "**Determinação Das Melhores Curvas De Controle Volt-Var Para Inversores Inteligentes Usando Algoritmo Evolucionário**", obtendo a nota 9,5 (NOVE E MEIO) e conceito APROVADO.

A handwritten signature in blue ink, reading "Jonatas Boas Leite", is written over a horizontal line.

Prof. Dr. Jonatas Boas Leite
- Orientador-

A handwritten signature in blue ink, reading "João Paulo", is written over a horizontal line.

João Paulo Martins Veloso
- Discente-

A handwritten signature in blue ink, reading "Lucas do Carmo Yamaguti", is written over a horizontal line.

Dr. Lucas do Carmo Yamaguti
- Membro da Banca -

A handwritten signature in blue ink, reading "Mikael de Freitas Amaral", is written over a horizontal line.

Mestrando Mikael de Freitas Amaral
- Membro da Banca -

DEDICATÓRIA

Dedico este trabalho à minha mãe, cuja fé no meu potencial sempre me inspirou a seguir em frente; ao meu pai, que me apoiou em cada decisão; e a todos que estiveram ao meu lado, oferecendo apoio, força e companhia durante essa jornada.

AGRADECIMENTOS

Agradeço a minha família, pelo amor, apoio incondicional e incentivo em todos os momentos, especialmente nos mais desafiadores, Marcia Maria Martins, Silas de Souza Veloso e Filipe Martins Veloso.

Agradeço a Deus pela saúde, pela serenidade e pela capacidade de perseverar durante toda a trajetória acadêmica.

Ao meu orientador Prof. Dr. Jonas Boas Leite pela paciência, orientação e dedicação, que foram fundamentais para o desenvolvimento deste trabalho.

Aos meus amigos Lucas, Felipe, Vitor, Gabriel, Li, Fernando e Giovanni, pela parceria, trocas de conhecimentos e pelo companheirismo ao longo dessa jornada.

Aos professores que fizeram parte da minha formação acadêmica. Cada um, com seu conhecimento, dedicação e exemplo, contribuiu de forma essencial para o meu crescimento pessoal e profissional.

E a todos que, de alguma forma, contribuíram direta ou indiretamente para a realização deste trabalho, o meu sincero muito obrigado.

“O homem não teria alcançado o possível se, repetidas vezes, não tivesse tentado o impossível.”

— Autor desconhecido

RESUMO

Neste trabalho é apresentado uma metodologia para a otimização das curvas de controle Volt-VAr e Volt-Watt aplicados aos inversores inteligentes em redes de distribuição de energia elétrica, para isso, utilizara-se o algoritmo genético implementados na linguagem C#. Visando melhorar o perfil de tensão e reduzir as perdas ativas no sistema teste de 134, operando em 13,8 kV, desenvolveu-se um algoritmo em que, cada indivíduo representa uma configuração de instalação e tipo de controle dos inversores, onde avaliou-se a eficiência através de uma função de aptidão. Realizaram-se duas fases experimentais, sendo a primeira delas com 10 gerações e 50 indivíduos, na segunda fase utilizou-se 20 gerações de 100 indivíduos. Os resultados obtidos indicaram que o aumento dos parâmetros do algoritmo genético, proporcionou maior convergência e desempenho das soluções, reduzindo as perdas e mantendo as tensões dentro dos limites desejáveis (entre 0,93 e 1,05 pu). Portanto, tem-se que o uso de algoritmos evolutivos, é uma alternativa eficiente para coordenar inversores inteligentes em sistemas de distribuição.

Palavras-chave: Algoritmo Genético. Inversores Inteligentes. Controle Volt-VAr. Controle Volt-Watt. Otimização. Sistemas de Distribuição.

ABSTRACT

This work presents a methodology for optimizing the Volt-VAr and Volt-Watt control curves applied to smart inverters in electric power distribution networks, using genetic algorithms implemented in C#. Aiming to improve the voltage profile and reduce active power losses in a 134-bus system operating at 13.8 kV, an algorithm was developed in which each individual represents a specific installation configuration and inverter control type, with performance evaluated through a fitness function. Two experimental phases were carried out: the first with 10 generations and 50 individuals, and the second with 20 generations and 100 individuals. The results indicated that increasing the algorithm parameters provided greater convergence and improved solution performance, reducing losses and maintaining voltages within the desired limits (0,93 and 1,05 pu). Therefore, the use of evolutionary algorithms proves to be an efficient alternative for coordinating smart inverters in distribution systems.

Keywords: Genetic Algorithms. Smart Inverters. Volt-VAr Control. Volt-Watt Control. Optimization. Distribution Systems.

LISTA DE FIGURAS

Figura 1 – Fluxo unidirecional x fluxo bidirecional	16
Figura 2 – Gráfico de controle (potência ativa).....	20
Figura 3 – Gráfico curva de controle Volt-VAr	19
Figura 4 – Diagrama de classes do sistema elétrico implementado.....	24
Figura 5 – Exemplo de recombinação.....	32
Figura 6 – Exemplo de mutação.....	32
Figura 7 – Gráfico dos valores obtidos na primeira rodada de simulações	35
Figura 8 – Valores obtidos na segunda rodada de simulações	37
Figura 9 – Gráfico das magnitudes de tensão sem unidades geradoras.	38
Figura 10 – Magnitudes de tensão (10 gerações × 50 indivíduos).....	39
Figura 11 – Magnitudes de tensão (50 gerações × 100 indivíduos).....	42
Figura 12 – Diagrama adaptado da rede de 134 nós	47

LISTA DE TABELAS

Tabela 1 - Valores obtidos com número de gerações 10 e indivíduos 50	36
Tabela 2 - Valores obtidos com número de gerações 50 e indivíduos 100	38

LISTA DE SIGLAS E ABREVIATURAS

ABSOLAR	Associação Brasileira de Energia Solar Fotovoltaica
AE	Algoritmo Evolucionário
ANEEL	Agência Nacional de Energia Elétrica
EPE	Empresa de Pesquisa Energética
EPRI	Electric Power Research Institute
IEEE	Institute of Electrical and Electronics Engineers
MME	Ministério de Minas e Energia
RED	Recursos Energéticos Distribuídos

LISTA DE VARÁVEIS

σ - Desvio da função fitness

δ - Variância da função fitness

S - Potência complexa

I - Corrente complexa

V_{para} - Cálculo tensão em cada barra

P_{loss} - Cálculo das perdas ativas

f_m - Fitness média

$f_{fitness}$ - Cálculo da função fitness

D - Demanda

T_m - Taxa de mutação

T_r - Taxa de recombinação

SUMÁRIO


1. INTRODUÇÃO	16
1.1. Objetivo Geral	17
1.2. Objetivos Específicos	17
1.3. Revisão da Literatura	18
2. METODOLOGIA	20
2.1. Funções de controle	20
2.1.1. <i>Função Volt-Watt</i>	20
2.1.2. <i>Função Volt-VAr</i>	21
2.2. Métricas de desempenho.....	22
2.3. Algoritmos evolutivos	22
3.FORMULAÇÃO MATEMÁTICA DO ALGORITMO EVOLUTIVO E ATRIBUTOS	25
3.1. Corrente injetada na barra	25
3.2. Queda de Tensão ao Longo dos Ramos	25
3.3. Cálculo das perdas ativas.....	26
3.4. Função fitness	27
3.5. Inicialização da população.....	27
3.6. Atributo tipo.....	28
3.7. Atributo curva.....	28
3.8. Atributo <i>blnst</i>	28
4. IMPLEMENTAÇÃO DO ALGORITMO E CONFIGURAÇÃO DO SISTEMA	30
4.1. Rede de 134 nós trifásica	30
4.2. AJUSTE DO ALGORITMO GENÉTICO EM C#.....	30
4.3. Número de indivíduos e gerações	30
4.4. Operadores genéticos e parâmetros	31
4.4.1. <i>Seleção</i>	31
4.4.2. <i>Recombinação</i>	31
4.4.3. <i>Mutação</i>	32
4.4.4. <i>Número de gerações (Ng)</i>	32
4.4.5. <i>Número de populações (Np)</i>	33
4.4.6. <i>Taxa de Recombinação e Taxa de Mutação</i>	33
4.4.7. <i>Taxa de Recombinação (Tr)</i>	33

4.4.8. Taxa de Mutação (T_m)	34
5. RESULTADOS E DISCUSSÕES	35
5.1. Condições de simulação	35
5.2. Valores obtidos com inversor inteligente.	35
5.2.1. Valores obtidos com número de gerações 10 e indivíduos 50	35
5.2.2. Valores obtidos com número de gerações 50 e indivíduos 100	37
5.3. Análise das Magnitudes de Tensão em Três Cenários Operacionais	40
5.3.1. Sistema sem geradores	40
5.3.2. Magnitudes de tensão para o segundo caso.....	41
5.3.2. Magnitudes de tensão para o terceiro caso	41
5.4. Considerações gerais dos resultados	42
6. CONCLUSÃO	44
REFERÊNCIAS.....	45
ANEXO A – Descrição do Sistema de Teste Utilizado (Rede IEEE 134 Barras) .	47

1. INTRODUÇÃO

Os sistemas de distribuição de energia elétrica são projetados para operar de maneira radial, com fluxo unidirecional, da subestação até as cargas. Devido ao avanço tecnológico, mudanças climáticas e incentivos governamentais, houve um aumento na utilização de recursos energéticos distribuídos, tais como geração eólica e solar fotovoltaica, provocando-se fluxo de energia bidirecional (Seguin *et al.*, 2016). Em estudo realizado pela Empresa de Pesquisa Energética (EPE) e coordenado pelo Ministério de Minas e Energia (MME), dados mostram que a média do consumo de energia no Brasil pode aumentar cerca de 2,1% ao ano até 2034. De acordo com a Associação Brasileira de Energia Solar Fotovoltaica (ABSOLAR), a geração de energia solar no Brasil, superou os 55 gigawatts (GW), dos quais 1,6GW foram instalados no ano de 2025. Na Figura 1 disponibilizada pelo Energy Atlas (2018), tem-se o comparativo do fluxo unidirecional com o fluxo bidirecional.

Figura 1 – Fluxo unidirecional x fluxo bidirecional



Fonte: Energy Atlas (2018)

A implantação dos Recursos Energéticos Distribuídos (RED) oferece benefícios, tais como, melhoria na eficiência energética, redução de perdas técnicas, diminuição do impacto ambiental e apoio ao controle de tensão. Porém, tem-se que a alta penetração pode ocasionar impactos adversos, tais como, aumento de tensão, problemas de proteção, fluxo reverso de potência e no emprego de um maior número de operações em reguladores de tensão e banco de capacitores (Walling *et al.*, 2008). Tem-se que a principal limitação à interconexão de RED, é devido ao impacto sobre a tensão (EPRI, 2017).

Na geração solar fotovoltaica, tem-se que geralmente a produção máxima não coincide com a demanda máxima, além disso, devido as condições meteorológicas existe variabilidade, fazendo-se com que ocorra o aumento na atuação dos dispositivos controladores de tensão, como reguladores e capacitores (Sunderman *et al.*, 2014). De acordo com o padrão IEEE 1547 (IEEE, 2018), o RED deve ser capaz de responder às variações de tensão, através do ajuste da injeção e absorção de potência reativa, e quando necessário, limitar a potência ativa.

1.1. Objetivo Geral

Este trabalho de graduação tem como objetivo principal, desenvolver e implementar uma metodologia baseada no uso do algoritmo genético na otimização das curvas de controle Volt-VAr e Volt-Watt, aplicadas a inversores inteligentes em redes de distribuição de energia elétrica, visando reduzir as perdas ativas do sistema.

1.2. Objetivos Específicos

Implementar o modelo computacional da rede elétrica em linguagem C#, representando barras, ramos e geradores de forma orientada a objetos.

Configurar as curvas de controle Volt-VAr e Volt-Watt para os inversores inteligentes, permitindo o ajuste automático da potência ativa e reativa conforme a tensão na barra.

Desenvolver e aplicar um algoritmo genético capaz de definir, de maneira otimizada, a localização dos inversores e os tipos de curvas de controle mais adequados para cada ponto da rede.

Avaliar o desempenho da metodologia em diferentes configurações de população e número de gerações, analisando a convergência, estabilidade e eficiência das soluções obtidas.

1.3. Revisão da Literatura

Muitos trabalhos investigam o impacto da geração distribuída no perfil de tensão e através dessas investigações, desenvolveram métodos capazes de alocar as unidades geradoras de maneira ótima. Dentre os métodos utilizados, está o dos algoritmos evolutivos, que é utilizado para definir localização, capacidade e fator de potência ideais de unidades fotovoltaicas conectadas a rede. Trabalhos como os de Huy *et al.* (2020) e Purlu e Turkay (2022) demonstram que os algoritmos evolutivos são uma ferramenta importante quando se tem o objetivo de minimizar as perdas e melhorar o perfil de tensão.

Nos trabalhos de Kim (2017) e Lee, Kim e Cho (2020), utilizam-se os algoritmos evolutivos para definir a instalação ótima de unidades fotovoltaicas, para isso, leva-se em consideração o uso e curvas Volt-VAr, embora os pontos de ajuste dessas curvas ainda sejam configurados de maneira fixa. Atualmente, algumas pesquisas tratam os pontos das curvas de controle dos inversores como variáveis de decisão, tal método permite a otimização conjunta entre localização, capacidade e controle, como discutido por Jaramillo-Leon *et al.* (2023) e (2024).

No contexto de inversores inteligentes, a literatura apresenta avanços relevantes sobre o impacto das funções Volt-VAr, Volt-Watt e controles combinados. Pesquisas como as de Chathurangi *et al.* (2021) avaliam diferentes padrões internacionais, como IEEE 1547 e California Rule 21, e mostram que a operação coordenada das funções reativas e ativas podem reduzir violações de tensão e melhorar a estabilidade do alimentador. Outros estudos, como os de Bello *et al.* (2018), exploram a seleção das melhores curvas por meio de análise multicritério, considerando perdas, violações de tensão e variabilidade.

Apesar dos avanços, observa-se uma lacuna na literatura no que diz respeito à otimização direta dos parâmetros das curvas de controle, especialmente quando aplicada a redes maiores e com múltiplos inversores operando simultaneamente. Boa parte dos trabalhos utiliza curvas pré-definidas, sem explorar totalmente o potencial de técnicas como os algoritmos genéticos para ajustar automaticamente os parâmetros de cada curva, considerando múltiplos objetivos e restrições.

Nesse cenário, o presente trabalho contribui ao utilizar um algoritmo evolutivo para otimizar diretamente os parâmetros das curvas Volt-Var e Volt-Watt de inversores inteligentes em uma rede realista de 134 barras, com o objetivo de melhorar o perfil de tensão e reduzir perdas de potência ativa. Essa abordagem segue a tendência moderna de tratar a configuração dos inversores como parte do processo de otimização, permitindo resultados mais precisos e adaptados às condições operativas da rede.

2. METODOLOGIA

Através do uso de inversor inteligente e de suas funções de controle, foi possível regular a tensão de saída de um sistema fotovoltaico. A seguir serão apresentadas as funções que controlam o sistema, e as métricas utilizadas para medir o desempenho do mesmo.


2.1. Funções de controle

Em um inversor inteligente, o controle de tensão, potência ativa ou potência reativa, é realizado através das funções de controle. Através de uma variável de entrada, que pode ser a tensão, é possível relacioná-la com a curva V por W, ou V por VAr.

2.1.1. Função Volt-Watt

A função de controle Volt-Watt atua no controle da potência ativa do sistema fotovoltaico. Na Figura 1 tem-se uma ilustração de como ocorre o controle da potência ativa, através da tensão medida.

Figura 2 – Gráfico de controle (potência ativa)



Fonte: Adaptado de (Freitas, 2020)


Para valores de tensão menores que V_1 , a potência ativa fornecida pelo sistema fotovoltaico é máxima. Entre os valores de V_1 e V_2 , a potência ativa é reduzida linearmente. Para valores de tensão acima de V_2 , a potência ativa é zerada, portanto o sistema fotovoltaico para de fornecer potência ativa.

Visando evitar o aumento de tensão, a função de controle Volt-Watt atua para limitar a potência ativa de saída, para Freitas et. Al. (2020), o controle exercido pela função Volt-Watt, é indicado quando o gerador fotovoltaico está em pleno funcionamento, porém, existe baixa demanda de consumo ou falta de equipamento regulador.

2.1.2. Função Volt-VAR

A função Volt-VAR tem como finalidade fornecer e absorver potência reativa de saída do inversor. Pode-se observar na Figura 2, a relação entre a tensão em pu e a potência reativa.

Figura 3 – Gráfico curva de controle Volt-VAR



Fonte: Adaptado de (Freitas, 2020)

Para valores positivos do eixo y, tem-se o fornecimento de potência reativa, portanto, para valores abaixo de V_2 tem-se o inversor atuando de maneira capacitiva, ou seja, com o intuito de aumentar o valor da tensão. Quando a tensão é menor que V_1 , o inversor fornece 100% da potência reativa. Entre V_1 e V_2 , a quantidade de potência reativa fornecida pelo inversor é reduzida. Entre V_2 e V_3 , o inversor se encontra na região conhecida como “zona morta”, não fornecendo e nem absorvendo potência reativa. Para valores maiores que V_3 , potência reativa é indutiva, ou seja, o inversor absorve potência. Entre V_3 e V_4 , a ocorre aumento na taxa que o inversor absorve potência.

2.2. Métricas de desempenho

As seguintes métricas são utilizadas para avaliar e comparar o desempenho das funções de controle dos inversores inteligentes: fitness média (f_m), desvio da fitness (σ) e a variância da fitness (δ). A variância é utilizada na estatística para quantificar o grau de dispersão dos dados em relação à média, sendo obtida através da média dos quadrados dos desvios de cada valor, em relação ao valor médio, sendo possível, avaliar o quanto os dados se espalham no conjunto. O desvio padrão corresponde à raiz quadrada da variância. Segundo Montgomery e Runger (2018), ambas as medidas são fundamentais para analisar variabilidade e comportamento de dados em aplicações de engenharia e ciência aplicada. Para o desvio da função fitness (σ) tem-se:

$$\sigma = \sqrt{\frac{\sum (f_i - f_m)^2}{n}} \quad (1)$$

Para a o cálculo da variância, tem-se:

$$\delta = \frac{\sum (f_i - f_m)^2}{n} \quad (2)$$

2.3. Algoritmos evolutivos

O termo algoritmo genético é um conceito com técnicas inspiradas na teoria da evolução natural de Charles Darwin.

Para se realizar a simulação de um processo evolutivo em um computador, necessita-se do seguinte (Coello *et al.*, 2002):

- Uma representação de soluções potenciais para o problema;
- Uma maneira de criar uma população inicial de soluções potenciais;
- Uma função de avaliação que desempenha o papel do meio ambiente e, soluções de elite em termos de sua “adequação”;
- Operadores genéticos que alteram a composição da prole gerada, normalmente, recombinação e mutação;
- Valores para vários parâmetros que o algoritmo evolutivo usa (tamanho da população, probabilidades de aplicação de operadores genéticos, etc).


Para definir formalmente um Algoritmo Evolucionário (AE), seu modelo básico é descrito em termos matemáticos, permitindo a especificação exata dos vários parâmetros do AE. Nesta estrutura, cada AE está associado a um conjunto não vazio I de espaço dos indivíduos. Cada indivíduo $a \in I$ normalmente representa uma solução candidata para o problema que está sendo resolvido. Os indivíduos são frequentemente representados como um vetor (a), onde as dimensões do vetor são análogas aos genes de um cromossomo. Além disso, um indivíduo (a) é modificado conforme necessário pelas instâncias do AE.

Ao definir transformações populacionais, ou geracionais, Bäck (1996) denota a coleção resultante de μ indivíduos via I^μ , e denota transformações populacionais pela seguinte relação: $T: I^\mu \rightarrow I^\mu$, onde $\mu \in \mathbb{N}$. No entanto, algumas variantes do AE obtêm populações resultantes cujo tamanho não é igual ao de seus predecessores. Assim, esta estrutura geral representa uma transformação populacional por meio da relação $T: I^\mu \rightarrow I^{\mu'}$, indicando que populações sucessivas podem conter o mesmo ou diferentes números de indivíduos. Esta estrutura também representa todos os tamanhos de população, operadores evolutivos e parâmetros como sequências. Dessa forma, um AE é definido como (Coello *et al.*, 2002):

Seja I um conjunto não vazio do espaço de indivíduos, $\{\mu^{(i)}\}_{i \in \mathbb{N}}$ uma sequência em $\mathbb{Z}^+$ dos tamanhos da população pai, $\{\mu'^{(i)}\}_{i \in \mathbb{N}}$ a sequência em $\mathbb{Z}^+$ dos tamanhos

da população descendente, $\Phi: I \rightarrow \mathbb{R}$ uma função de aptidão, $\iota: \bigcup_{i=1}^{\infty} (I^{\mu})^{(i)} \rightarrow \{\text{verdadeiro}, \text{falso}\}$ o critério de parada, $\chi \in \{\text{verdadeiro}, \text{falso}\}$, r uma sequência $\{r^{(i)}\}$ de operadores de recombinação $r^{(i)}: \mathbb{X}_r^{(i)} \rightarrow \mathcal{T}\left(\Omega_r^{(i)}, \mathcal{T}\left(I^{\mu^{(i)}}, I^{\mu'^{(i)}}\right)\right)$, m uma sequência $\{m^{(i)}\}$ dos operadores de mutação $m^{(i)}: \mathbb{X}_m^{(i)} \rightarrow \mathcal{T}\left(\Omega_m^{(i)}, \mathcal{T}\left(I^{\mu^{(i)}}, I^{\mu'^{(i)}}\right)\right)$, s uma sequência $\{s^{(i)}\}$ dos operadores de seleção $s^{(i)}: \mathbb{X}_s^{(i)} \times \mathcal{T}(I, \mathbb{R}) \rightarrow \mathcal{T}\left(\Omega_s^{(i)}, \mathcal{T}\left(I^{\mu^{(i)} + \chi \mu^{(i)}}, I^{\mu^{(i+1)}}\right)\right)$, $\theta_r^{(i)} \in \mathbb{X}_r^{(i)}$ os parâmetros de recombinação, $\theta_m^{(i)} \in \mathbb{X}_m^{(i)}$ os parâmetros de mutação e $\theta_s^{(i)} \in \mathbb{X}_s^{(i)}$ os parâmetros de seleção. Na Figura 3, tem-se o diagrama de classes do modelo computacional que foi desenvolvido para representar a rede de distribuição e realizar o cálculo do fluxo de potência trifásico.

Figura 4 – Diagrama de classes do sistema elétrico implementado



Fonte: Adaptado do LAPSEE.

3.FORMULAÇÃO MATEMÁTICA DO ALGORITMO EVOLUTIVO E ATRIBUTOS

Neste trabalho, utiliza-se algoritmo que visa otimizar o perfil de tensão da rede de distribuição, para isso realiza-se o controle da potência ativa e reativa dos geradores distribuídos. Primeiramente, é necessário modelar matematicamente o fluxo de potência trifásico e as curvas de controle Volt-Watt e Volt-Var. A seguir são apresentadas as principais equações que descrevem o comportamento elétrico da rede.

3.1. Corrente injetada na barra

Tal equação é derivada da definição de potência complexa, o cálculo da potência ativa e reativa foi realizado considerando as grandezas elétricas em sua forma fasorial, onde:

$$S = P + jQ = V \times I^* \quad (3)$$

No modelo implementado, utilizou-se números complexos para se obter os valores das tensões e correntes, para o cálculo da corrente tem-se:

$$I = \left(\frac{S}{V} \right)^* \quad (4)$$

Com a equação, é possível determinar a corrente injetada em cada barra, e com os valores obtidos, calcular o fluxo de potência. Abaixo tem-se o código utilizado para se obter a corrente injetada.

```
ramos[0].deBarra.I[i] =  
Complex.Conjugate(ramos[0].deBarra.S[i]/ramos[0].deBarra.V[i]);
```

3.2. Queda de Tensão ao Longo dos Ramos

A variação de tensão entre duas barras conectadas por um ramo, é calculada levando-se em consideração a impedância em série da linha e o acoplamento entre fases, tal relação se dá pela seguinte equação:

$$V_{para} = V_{de} - Z_{ramo} \cdot I_{ramo} \quad (5)$$

No algoritmo definem-se V_{de} e V_{para} como sendo vetores de tensão complexa (3x1) das barras de origem para as barras de destino. Z_{ramo} é a matriz de impedância 3x3, onde estão contidas as impedâncias próprias e mutuas entre as fases. I_{ramo} é definido como o vetor de corrente trifásica que circula pelo ramo.

Abaixo, tem-se exemplo do código utilizado para se obter a queda de tensão ao longo dos ramos:

```
Ramo.paraBarra.V[i] = ramo.deBarra.V[i];
Ramo.paraBarra.V[i] -= ramo.zRamo[i][j]*ramo.J[j];
```

3.3. Cálculo das perdas ativas

As perdas ativas da rede são obtidas através da soma das perdas de cada ramo e fase, sendo essas, proporcionais ao quadrado da corrente e à resistência em série.

$$P_{loss} = \sum_{ramos} \sum_{fases} |I_{ramo, fase}|^2 \cdot R_{ramo, fase} \quad (6)$$

Tal grandeza está diretamente relacionada com cálculo da função *fitness*, pois quanto menor as perdas, melhor deve ser o desempenho do sistema. No código em C#, as perdas foram obtidas através do código abaixo:

```
double pl = 0;
for (int i = 0; i < ramos.Length; i++)
{
    for (int f = 0; f < 3; f++)
        pl += Math.Pow(ramos[i].J[f].Magnitude, 2) * ramos[i].zRamo[f][f].Real;
}
```

3.4. Função fitness

A função *fitness* tem como papel, realizar a seleção natural, classificando e identificando os indivíduos mais aptos para compor as próximas gerações. Para realizar tal avaliação, o algoritmo utiliza a seguinte expressão:

$$f_{fitness} = \frac{D}{P_{loss}} \quad (7)$$

A função *fitness* é inversamente proporcional às perdas ativas da rede. Quanto menores as perdas, maior é o valor da *fitness*, assim *fitness* com maior valor, é considerada a melhor solução.

3.5. Inicialização da população

A inicialização tem como objetivo gerar soluções candidatas diversas, cada indivíduo é composto por um vetor de geradores distribuídos, onde cada gerador possui três parâmetros principais: barra de conexão, tipo de curva de controle e a curva específica utilizada. Os parâmetros são inicializados aleatoriamente.

```
População[i].cromossomo[j].bInst=
    redeD.barras[new Random().Next(1,
    redeD.barras.Length)];
População[i].cromossomo[j].tipo = new Random().Next(2);
```

Cada indivíduo representa uma configuração diferente de posicionamento e controle dos geradores. Tal diversidade inicial é fundamental para o processo evolutivo, pois permite o algoritmo explorar diversas estratégias e convergir para soluções mais eficientes.

3.6. Atributo tipo

O atributo “tipo” tem como objetivo definir qual tipo de controle de gerador deve ser utilizado, tem-se as seguintes configurações:

- Tipo = 0 corresponde ao controle Volt-Watt, nesse modo de operação, conforme a tensão aumenta, o gerador reduz gradualmente a potência ativa injetada, pois previne sobretensões.
- Tipo = 1 representa o controle Volt-VAr, a regulação do perfil de tensão da rede é através do ajuste da potência reativa realizado pelo gerador, tal regulação ocorre de acordo com a variação de tensão.

3.7. Atributo curva

O atributo “curva” tem como função indicar a configuração de curva que deve ser utilizada. Cada curva tem diferentes tipos de tensão e potência armazenados em matrizes, e são utilizadas para definir o comportamento do gerador de acordo com as variações de tensão.

O valor de curva varia entre 0 e 2, e é selecionado de maneira aleatória na fase de inicialização da população. Durante a simulação, utiliza-se o atributo “curva”, para acessar os valores contidos nas matrizes *Vcurvas*, *Pcurvas*, *VQcurvas* e *Qcurvas*. Desta forma, o algoritmo é capaz de testar diferentes configurações para cada gerador.

```
public double [][] Vcurvas; // Limites de tensão para curvas Volt/Watt
public double [][] Pcurvas; // Potência associada às curvas Volt/Watt
public double [][] VQcurvas; // Limites de tensão para curvas Volt/Var
public double [][] Qcurvas; // Potência reativa associada às curvas
```

3.8. Atributo *blnst*

O atributo *blnst* representa a barra onde o gerador pode ser instalado. Durante a inicialização da população, o valor do atributo *blnst* é obtido de maneira aleatória, de modo que cada gerador seja posicionado em diferentes locais da rede, tal

aleatoriedade permite que o algoritmo explore diversas combinações. A posição da instalação do gerador afeta diretamente o cálculo do fluxo e potência, portanto o afetando diretamente no valor da função fitness.

Ao longo das gerações, operadores genéticos podem modificar o valor de *blnst*, permitindo que o gerador seja realocado para uma posição onde ocorra otimização.

4. IMPLEMENTAÇÃO DO ALGORITMO E CONFIGURAÇÃO DO SISTEMA

4.1. Rede de 134 nós trifásica

Para o teste foi proposto utilizar uma rede de 134 nós, trata-se de um modelo utilizado para se realizar estudos, análises técnicas e no desenvolvimento de algoritmos relacionados a problemas de distribuição de energia elétrica, como confiabilidade no fornecimento, posicionamento ótimo de dispositivos de proteção e controle, e localização de faltas. Na Figura 12 contida no ANEXO A, encontra-se o diagrama adaptado da rede 134 nós.

4.2. AJUSTE DO ALGORITMO GENÉTICO EM C#

A otimização das curvas de controle da função inteligente Volt-Watt e Volt-VAR foi realizado através de um algoritmo evolucionário, utilizando-se linguagem de programação C#. Para o fluxo de potência, utilizou-se também algoritmo desenvolvido em C#, para realização do cálculo.

Existem diversas formas de se representar cromossomos das soluções candidatas, porém, a mais utilizada é a binária. No entanto, a forma decimal também pode ser utilizada, sendo muitas vezes até mais rápida e precisa que a abordagem binária (Michalewics, 1996).

Neste trabalho, a forma decimal foi empregada para representar os cromossomos das soluções candidatas. Cada cromossomo é constituído por número da barra, tipo e curva.

4.3. Número de indivíduos e gerações

Para esse trabalho, realizou-se primeiramente experimentos com número de indivíduos de 10 e 50 gerações, e na sequência aumentou-se o número de indivíduos para 50 e gerações igual a 100.

4.4. Operadores genéticos e parâmetros

Os operadores genéticos têm como função modificar a composição da prole, durante o processo de evolução da população. Tem-se que os principais operadores genéticos são: *Seleção*, *Recombinação* e *Mutação*.

4.4.1. Seleção


Utilizando-se os valores obtidos do cálculo de aptidão dos cromossomos através da função objetivo, tem-se que os indivíduos são ordenados em ordem decrescente do desempenho. Analogamente a seleção natural, tem-se que os mais aptos, são os que possui maiores chances de sobreviver e transferir suas características genéticas para as próximas gerações. Realiza-se a seleção do indivíduo com melhor colocação no ranking de aptidão. No algoritmo genético utilizado nesse trabalho, é selecionado o cromossomo mais apto de cada simulação, baseando-se no *fitness*.

4.4.2. Recombinação

O operador genético de recombinação tem como responsabilidade mesclar o material genético dos cromossomos selecionados, utilizando os indivíduos da geração anterior, para gerar os da nova geração.

No algoritmo genético, é utilizado o método de recombinação uniforme, os valores de cada gene do cromossomo da nova geração, são herdados de forma aleatória dos “cromossomos pais” mais aptos. Como exemplo, tem-se que para definir o número de barra mais apto, escolhe-se esse valor de um dos pais que possui melhor desempenho, então tais genes, é transmitido para o cromossomo filho da nova geração. No presente trabalho, para cada par de pais selecionados são gerados dois filhos, que herdam combinações distintas dos genes de ambos os pais. Na Figura 5 tem-se um exemplo de recombinação:

Figura 5 – Exemplo de recombinação




Fonte: Elaborado pelo autor.

4.4.3. Mutação

A função do operador genético de mutação é introduzir variabilidade genética a prole, pequenas alterações genéticas são promovidas por esse operador. Tal mecanismo é utilizado para aumentar a probabilidade de se alcançar uma melhor solução global, pois ele evita que o algoritmo convirja de maneira prematura.

Na implementação utilizada neste trabalho, tem-se que a mutação atua de forma a modificar o valor dos genes de um cromossomo, o exemplo pode ser observado na Figura 6.

Figura 6 – Exemplo de mutação



Fonte: Elaborado pelo autor.

4.4.4. Número de gerações (N_g)

O parâmetro define a quantidade de execuções que o algoritmo evolucionário deve realizar ao longo do processo. Cada geração significa um ciclo completo de avaliação de população, como seleção, recombinação e mutação. Portanto, tem-se

que o valor de N_g , determina a quantidade de tempo que o algoritmo tem para explorar o espaço de busca. O parâmetro N_g definido com um número pequeno, pode levar a resultados incorretos, pois devido a N_g ser baixa pode ocorrer convergência prematura. Um número N_g elevado, resulta em um aumento do custo computacional, podendo também garantir uma melhora significativa nos resultados.

4.4.5. Número de populações (N_p)

O parâmetro N_p define a quantidade de soluções candidatas que compõem cada geração do algoritmo genético, ou seja, determina o número de indivíduos que são avaliados em cada iteração.

Para um valor pequeno de N_p , tem-se que o custo computacional também é baixo, porém pode ocorrer uma limitação na diversidade genética da população, podendo ocorrer convergência prematura. Um valor grande de N_p amplia o espaço de busca, trazendo soluções mais diversas, porém, exige maior tempo de processamento computacional.

4.4.6. Taxa de Recombinação e Taxa de Mutação

No contexto dos algoritmos genéticos, tem-se dois parâmetros fundamentais para eficiência da busca, são eles: taxa de recombinação (T_r) e a taxa de mutação (T_m). Ambos determinam a forma de como a população de soluções evolui no decorrer das gerações, também influenciam diretamente na qualidade e velocidade da convergência.

4.4.7. Taxa de Recombinação (T_r)

A taxa de recombinação define a probabilidade de dois indivíduos ao serem selecionados como pais, combinarem seus cromossomos para gerarem novos indivíduos. Tal processo promove a exploração estruturada do espaço de busca. No algoritmo desenvolvido, adota-se $T_r = 0,8$, ou seja, em 80% dos casos, o cruzamento

entre os dois pais deve ser realizado, nos 20% restantes, o indivíduo é transmitido diretamente para a próxima geração, sem sofrer nenhuma alteração.

Um valor elevado de T_r faz com que ocorra aumento na diversidade genética da população, porém, pode comprometer a preservação de boas soluções, pois se T_r for muito alto, de valor próximo 1, quase nenhuma solução deve ser preservada na população seguinte, ou seja, soluções de alta qualidade pode ser quebradas em partes ao serem cruzadas. Tal fenômeno é amplamente discutido na literatura, especialmente na hipótese dos *building blocks*, descrita por Goldberg (1989), onde o autor afirma que: “estruturas parciais de boa qualidade devem ser preservadas ao longo das gerações para que o algoritmo mantenha seu potencial evolutivo”.

4.4.8. Taxa de Mutação (T_m)

O parâmetro de taxa de mutação tem como função definir a probabilidade de alteração aleatória em um ou mais genes do indivíduo, visando garantir que novas características surjam na população e prevenindo a convergência prematura. Segundo Goldberg (1989), a mutação atua como um operador fundamental para manter a variabilidade genética, impedindo que o algoritmo fique restrito apenas às combinações já presentes na população.

No algoritmo, define-se a taxa de mutação $T_m=0,4$, ou seja, existe 40% de probabilidade que o indivíduo gerado sofra mutação em algum de seus genes, sendo elas, alterações na mudança de barra de instalação, tipo de controle ou curva de operação do inversor inteligente.

Se um valor muito baixo for atribuído a T_m , pode ocorrer perda na diversidade genética, levando o AE a ficar preso em soluções sub-ótimas, pois devido a taxa ser baixa, a população tende a ficar formada apenas por combinações de genes já existentes. Valores elevados atribuídos a T_m , pode tornar a busca excessivamente aleatória, prejudicando a convergência.

5. RESULTADOS E DISCUSSÕES

Nesta seção tem-se os resultados obtidos através da aplicação do algoritmo evolucionário na otimização das curvas de controle Volt-VAr e Volt-Watt em inversores inteligentes conectados à rede de 134 nós, e são analisados os valores obtidos após o emprego dos inversores inteligentes.

5.1. Condições de simulação

Na simulação foi utilizado um computador com as seguintes especificações:

- Intel Core i5 8250U 1.60GHz
- Memória RAM de 20GB 2400 MHz

Utilizou-se a linguagem de programação C# para implementar o algoritmo genético e calcular o fluxo de potência. Considerou-se duas fases experimentais, sendo a primeira utilizando 10 gerações e 50 indivíduos, e a segunda com 50 gerações e 100 indivíduos. Realizou-se 25 simulações independentes.

5.2. Valores obtidos com inversor inteligente.

Nesta seção será apresentado os valores obtidos de acordo com as curvas de controle e o tipo de função utilizada nas simulações.

5.2.1. Valores obtidos com número de gerações 10 e indivíduos 50

Foram realizadas 25 simulações com o algoritmo na configuração com o número de gerações igual a 10 e indivíduos igual a 50. Na Tabela 1 estão contidos dados como *fitness*, barra onde os três geradores foram instalados, curva e tipo.

Tabela 1 - Valores obtidos com número de gerações 10 e indivíduos 50

Simulação	Fitness	Barra Instalada [G1;G2;G3]	Curva [G1;G2;G3]	Tipo [G1;G2;G3]
1	1,1768582314181117	[107;111;38]	[1;0;2]	[0;1;0]
2	1,2632952017142811	[126;125;28]	[1;0;2]	[1;1;1]
3	1,3081650458187997	[12;82;106]	[1;1;0]	[1;1;1]
4	1,3134369020216938	[34;02;99]	[0;1;0]	[0;0;1]
5	1,2367032965281313	[71;26;115]	[0;2;0]	[0;0;0]
6	1,3134369020216938	[04;63;93]	[1;2;2]	[1;1;1]
7	1,2869774275125048	[31;136;30]	[0;2;0]	[1;0;1]
8	1,2797704221768786	[134;65;106]	[1;2;0]	[1;1;1]
9	1,2797704221768786	[44;27;04]	[2;0;0]	[0;1;1]
10	1,2869774275125048	[67;41;72]	[2;1;0]	[0;1;0]
11	1,3111944094266879	[107;68;91]	[2;2;0]	[0;0;0]
12	1,3134369020216938	[41;27;93]	[2;0;1]	[0;0;1]
13	1,2536584540470630	[96;106;52]	[2;2;2]	[0;1;0]
14	1,2878888285440144	[51;11;63]	[0;2;2]	[1;1;1]
15	1,3081650458187997	[89;131;88]	[2;1;0]	[1;0;0]
16	1,1738512066056526	[15;63;54]	[0;1;2]	[1;1;0]
17	1,3081650458187997	[30;136;81]	[2;1;2]	[0;0;1]
18	1,2748892838312824	[48;130;97]	[2;2;1]	[1;1;1]
19	1,3100164485122991	[23;28;90]	[2;2;1]	[0;0;1]
20	1,2632952017142811	[25;51;84]	[0;0;1]	[1;0;0]
21	1,3134369020216938	[68;134;93]	[1;0;1]	[1;0;1]
22	1,3081650458187997	[60;126;90]	[0;2;0]	[1;0;0]
23	1,3134369020216938	[22;32;93]	[0;0;2]	[0;1;0]
24	1,2959124199901710	[6;58;85]	[2;2;2]	[1;1;1]
25	1,2959124199901710	[78;126;120]	[1;0;0]	[1;0;1]

Fonte: Elaborado pelo autor.


Com os dados da tabela 1, obteve-se a média da fitness, tem-se: $f_{média} = 1,2830726318033832$

Com o valor $f_{média}$ foi calculado o desvio padrão, obteve-se o seguinte resultado: $\sigma = 0,03801361523562009$

A variância obtida foi: $\delta = 0,0014450349432817678$

O valor que mais se aproximou da média foi 1,2869774275125048, obtido nas simulações 7 e 10. Na Figura 7, tem-se o valor das frequências em que os resultados das simulações foram obtidos.

Figura 7 – Gráfico dos valores obtidos na primeira rodada de simulações



Fonte: Elaborado pelo autor.

Apesar de a média ter se aproximado do valor ótimo, observa-se que houve grande dispersão entre os resultados. Portanto, quando se tem número de populações e gerações reduzidos, o algoritmo pode não alcançar a solução ótima. O máximo fitness obtido foi 1,3134369020216938, valor que foi obtido nas simulações 4, 7, 12, 21 e 23.

5.2.2. Valores obtidos com número de gerações 50 e indivíduos 100

Realizou-se também 25 simulações com o algoritmo na configuração com o número de gerações igual a 50 e indivíduos igual a 100. Na tabela 2 estão contidos dados como fitness, barra onde o gerador foi instalado, curva e tipo.

Tabela 2 - Valores obtidos com número de gerações 50 e indivíduos 100

Simulação	Fitness	Barra Instalada [G1;G2;G3]	Curva [G1;G2;G3]	Tipo [G1;G2;G3]
1	1,3134369020216938	[83;115;107]	[1;2;0]	[1;0;0]
2	1,3134369020216947	[71;38;16]	[0;2;1]	[0;0;1]
3	1,3114779077796719	[62;94;13]	[2;2;2]	[0;0;0]
4	1,3134369020216947	[89;29;81]	[1;1;1]	[1;0;1]
5	1,3134369020216947	[49;10;48]	[2;2;2]	[0;0;0]
6	1,3134369020216938	[128;36;93]	[2;2;1]	[0;0;1]
7	1,3122656393596868	[68;98;124]	[1;0;0]	[1;1;1]
8	1,3111944094266879	[75;84;91]	[2;1;2]	[0;0;0]
9	1,3134369020216947	[93;36;73]	[0;2;1]	[0;0;1]
10	1,3134369020216947	[99;55;53]	[1;1;2]	[1;0;1]
11	1,3134369020216947	[133;122;124]	[2;2;2]	[0;0;1]
12	1,3134369020216947	[86;88;25]	[0;1;0]	[0;0;0]
13	1,3134369020216947	[87;47;93]	[0;2;0]	[1;0;1]
14	1,3134369020216947	[77;92;05]	[2;2;2]	[1;1;0]
15	1,3134369020216947	[60;11;120]	[1;2;0]	[1;0;1]
16	1,3134369020216938	[116;83;110]	[1;2;1]	[1;1;1]
17	1,3122656393596868	[117;76;20]	[0;2;0]	[0;0;1]
18	1,3134369020216938	[43;106;11]	[0;1;0]	[0;1;1]
19	1,3122656393596868	[108;28;10]	[1;2;0]	[0;1;1]
20	1,3134369020216938	[44;43;31]	[0;0;2]	[0;0;0]
21	1,3134369020216947	[20;69;93]	[2;0;0]	[1;1;1]
22	1,3134369020216938	[43;82;104]	[0;0;0]	[0;0;0]
23	1,3134369020216947	[27;124;123]	[0;0;1]	[1;0;0]
24	1,3122656393596868	[39;19;18]	[1;2;1]	[1;1;1]
25	1,3122656393596868	[80;130;10]	[1;0;2]	[0;0;1]

Fonte: Elaborado pelo autor.


Para os valores da segunda fase experimental, tem-se média de 1,3131910034715656. Assim, foi possível calcular o valor do desvio padrão, cujo valor foi de 0,00070833070104845.

Obteve-se também a variância: 0,0000005017325224458744

Observou-se que o valor mais próximo da média dos resultados, foi o 1,3134369020216938, cujo foi obtido em diversas configurações.

O valor máximo da *fitness* foi de 1,3134369020216947, sendo esse repetido diversas vezes nos valores simulados, e ficando muito próximo da média obtida. Na Figura 8 tem-se o gráfico dos valores das frequências dos valores obtidos:

Figura 8 – Valores obtidos na segunda rodada de simulações



Fonte: Elaborado pelo autor.

A proximidade entre valor máximo e a média, mostra que a solução ótima é atingida de forma consistente.


5.3. Análise das Magnitudes de Tensão em Três Cenários Operacionais

Para avaliar as magnitudes de tensão ao longo do sistema de tensão, analisou-se três situações distintas de operação. Cada cenário reflete diferentes condições de suporte de potência e, conseqüentemente, diferentes respostas do perfil de tensão.

5.3.1. Sistema sem geradores

No primeiro caso, analisou-se o sistema operando sem unidades geradoras conectadas as barras, tal condição representa o pior cenário, pois toda demanda, é suprida pela subestação principal. Observa-se que as magnitudes de tensão apresentam quedas mais acentuadas ao longo dos alimentadores, especialmente nas barras mais distantes da fonte. Na Figura 9 tem-se o gráfico das magnitudes de tensão, observa-se que entre as barras 109 e 120, as tensões ficam abaixo do limite inferior recomendado pela ANEEL (0,93 pu), podendo ocasionar risco de mau funcionamento de cargas sensíveis, aumento de perdas técnicas e redução da eficiência energética da rede.

Figura 9 – Gráfico das magnitudes de tensão sem unidades geradoras.




Fonte: Elaborado pelo autor

5.3.2. Magnitudes de tensão para o segundo caso

Nessa configuração intermediária, há injeção moderada de potência ativa ou reativa, capaz de reduzir a queda de tensão ao longo da rede. Os resultados mostram que as magnitudes de tensão melhoram de forma significativa em comparação ao primeiro cenário, porém algumas barras ainda permanecem próximas ao limite inferior, na Figura 10 tem-se o gráfico das magnitudes de tensão para o caso: 10 gerações × 50 indivíduos.

Figura 10 – Magnitudes de tensão (10 gerações × 50 indivíduos)




Fonte: Elaborado pelo autor.

5.3.2. Magnitudes de tensão para o terceiro caso

O terceiro caso representa a situação mais favorável, na qual os geradores distribuídos estão posicionados e controlados de forma otimizada. A injeção de potência ativa e reativa é ajustada adequadamente, garantindo que as magnitudes de tensão permaneçam dentro da faixa recomendada pela ANEEL para operação segura, entre (0,93 e 1,05 pu). Nesse cenário ideal, observa-se uma maior uniformidade no

perfil de tensão ao longo das barras, com eliminação de pontos críticos e redução significativa das quedas ao longo do alimentador. Além disso, o sistema apresenta desempenho energético superior, com redução de perdas e maior robustez operacional, na Figura 11 tem-se o gráfico das magnitudes de tensão para o caso: 50 gerações $\times$ 100 indivíduos.

Figura 11 – Magnitudes de tensão (50 gerações $\times$ 100 indivíduos)



Fonte: Elaborado pelo autor.

5.4. Considerações gerais dos resultados

Comparando-se as duas fases experimentais (10 gerações $\times$ 50 indivíduos e 50 gerações $\times$ 100 indivíduos), observa-se o impacto direto do aumento do número de gerações e da população na eficiência do algoritmo genético.

Na primeira operação (10 gerações $\times$ 50 indivíduos), obteve-se média fitness igual a 1,2830 com desvio padrão de 0,038 e variância de 0,001445. Observa-se maior dispersão em torno da média e menor convergência do algoritmo. Apesar de o valor

máximo da fitness ter sido de aproximadamente 1,3134, tal valor foi de baixa ocorrência.

Na segunda fase do experimento (50 gerações × 100 indivíduos), obteve-se 1,3131 de média fitness, valor próximo ao considerado ótimo. O desvio padrão foi de 0,0007 e a variância da ordem de $5,01 \times 10^{-7}$, mostrando alta estabilidade e convergência uniforme. O valor máximo da fitness foi de 1,3134, porém, dessa vez devido à alta ocorrência, ficou muito próximo da média.

Analisando-se os resultados obtidos nas duas fases, percebe-se que o aumento no número de gerações e indivíduos resulta em soluções mais consistentes, além disso, comparando-se as magnitudes de fases dos cenários apresentados, observa-se que a presença e o controle adequado dos geradores distribuídos desempenham papel fundamental na regulação da tensão, garantindo maior estabilidade e eficiência ao sistema elétrico.

6. CONCLUSÃO

O objetivo deste trabalho foi a otimização das curvas de controle Volt-VAr e Volt-Watt em inversores inteligentes, aplicou-se a uma rede de distribuição de 134 nós e utilizou-se algoritmos genéticos implementados em linguagem C#.

De acordo com os resultados obtidos, pode-se confirmar a eficácia da metodologia adotada. Com o uso das funções de controle, foi possível manter os níveis de tensão dentro dos limites requeridos pelas normas técnicas, e ao mesmo tempo reduzir perdas ativas no sistema. Através de análise estatística, evidenciou-se que a configuração com 50 gerações e 100 indivíduos apresentou maior consistência e estabilidade, para o sistema teste utilizado.

Portanto, tem-se que:

- O uso de inversores inteligentes contribui no desempenho operacional dos sistemas de distribuição, sendo utilizado como recurso complementar aos dispositivos tradicionais de controle de tensão.
- Tem-se o algoritmo genético como uma ferramenta eficiente para otimizar curvas de controle, cuja obtenção de soluções próximas ao ótimo global ocorrem em tempo computacional viável.
- O aumento de parâmetros como número de gerações e população é crucial para melhorar qualidade e confiabilidade dos resultados.

Pode-se dizer que os objetivos foram atingidos, visto que foi possível estudar a integração de recursos energéticos distribuídos em redes de distribuição, por meio do uso de técnicas de inteligência computacional.

REFERÊNCIAS

- ABSOLAR. Com 22% da matriz elétrica, energia solar é a 2ª maior fonte do país. 2025. Disponível em: <<https://agenciabrasil.ebc.com.br/meio-ambiente/noticia/>> Acesso em: 04/07/2025.
- CARLOS A. COELLO COELLO, DAVID A. VAN VELDHUIZEN, GARY B. LAMONT, “Evolutionary Algorithms for Solving Multi-Objective Problems,” Springer, 2a. ed., 2002
- DING, F., ZHANG, Y., SIMPSON, J., BERNSTEIN, A., AND VADARI, S. (2020). Optimal energy dispatch of distributed pvs for the next generation of distribution management systems. IEEE Open Access Journal of Power and Energy, 7, 287–295, 2020.
- ENERGY ATLAS. Facts and figures about renewables in Europe. 2018. Disponível em: < https://gef.eu/wp-content/uploads/2018/04/energyatlas2018_facts-and-figures-renewables-europe.pdf > Acesso em: 28/11/2025.
- EPE. Consumo de energia deverá crescer em média 2,1% ao ano nos próximos dez anos. 2024. Disponível em: <<https://agenciagov.ebc.com.br/noticias/202410/>> Acesso em: 04/07/2025.
- EPRI, Voltage regulation support from smart inverters. Technical report, Electric Power Research Institute, 2017.
- FREITAS, P.R.R.D., Impacto de funções inteligentes de inversores de sistemas fotovoltaicos na operação de redes de distribuição de energia elétrica. Master’s thesis, Universidade de São Paulo, 2019.
- GOLDBERG, D. E. Genetic Algorithms in Search, Optimization and Machine Learning. Addison-Wesley, 1989.
- IEEE (2018). Ieee standard for interconnection and interoperability of distributed energy resources with associated electric power systems interfaces. IEEE Std 1547-2018 (Revision of IEEE Std 1547-2003), 1–138, 2018.
- MONTGOMERY, D. C.; RUNGER, G. C. Applied Statistics and Probability for Engineers. 7. ed. Wiley, 2018.

RYLANDER, M., RENO, M.J., QUIROZ, J.E., DING, F., LI, H., BRODERICK, R.J., MATHER, B., AND SMITH, J., Methods to determine recommended feeder-wide advanced inverter settings for improving distribution system performance. In 2016 IEEE 43rd Photovoltaic Specialists Conference (PVSC), 1393–1398, 2016.

SEGUIN, R., WOYAK, J., COSTYK, D., HAMBRICK, J., AND MATHER, B., High-penetration pv integration handbook for distribution engineers. Technical report, National Renewable Energy Lab.(NREL), Golden, CO (United States), 2016.

T. BÄCK, “Evolutionary Algorithms in Theory and Practice,” Oxford University Press, New York, 1996.


WALLING, R.A., SAINT, R., DUGAN, R.C., BURKE, J., AND KOJOVIC, L.A., Summary of distributed resources impact on power delivery systems. IEEE Transactions on Power Delivery, 23(3), 1636–1644, 2008.

ZBIGNIEW MICHALEWICS “Genect Algorithms + Data Structures = Evolution Programs,” Springer, 3a. ed., 1996.

ANEXO A – Descrição do Sistema de Teste Utilizado (Rede IEEE 134 Barras)

Este anexo apresenta a descrição detalhada do sistema elétrico de distribuição utilizado como base para o desenvolvimento e avaliação da metodologia proposta neste trabalho. O sistema-teste adotado corresponde à rede IEEE de 134 barras, amplamente utilizada em estudos acadêmicos e análises de desempenho de algoritmos aplicados à operação de redes de distribuição. Na Figura 12 tem-se o sistema de teste utilizado.

Figura 12 – Diagrama adaptado da rede de 134 nós



Fonte: Adaptado do LAPSEE

1. Características Gerais do Sistema

O sistema IEEE 134 barras é um modelo de rede de distribuição radial trifásica, representativo de sistemas reais de média tensão. Suas principais características são:

- Número de barras: 134
- Tensão nominal: 13,8 kV
- Frequência: 60 Hz

2. Inversores Inteligentes e Barras de Controle

- A fim de investigar o impacto das curvas Volt-VAr e Volt-Watt, foram inseridos inversores inteligentes em barras selecionadas. Cada inversor possui:
- Capacidade nominal definida
- Curvas de controle programáveis
- Ajustes otimizáveis pelo algoritmo genético
- A escolha das barras segue o critério das regiões com maior variação de tensão.

3. Fluxo de Potência

O cálculo do fluxo de potência:

- É realizado fase a fase
- Considera a impedância entre as barras
- Calcula tensões, correntes e perdas
- Permite estimar a qualidade da solução encontrada pelo algoritmo genético
- Este modelo fornece as informações necessárias para a avaliação da função fitness.

4. Importância do Sistema de Teste

- A escolha da rede IEEE 134 barras garante:
- Reprodutibilidade dos resultados
- Comparabilidade com outros trabalhos da literatura
- Complexidade realista, incluindo trechos longos e carregados
- Cenários representativos de sobretensão e subtensão
- Validade acadêmica da metodologia desenvolvida
- Por essas razões, o sistema é apropriado para experimentos envolvendo otimização de curvas de controle de inversores.